

Sistem Rekomendasi Tanaman Berdasarkan Kondisi Tanah Menggunakan Sensor Tanah 8-in-1 dan Algoritma Decision Tree

Putra Eka Praja^a, Ade Silvia Handayani^{b*}, Nasron Nasron^c, Nyayu Latifah Husni^d, Asmawati Asmawati^e, Jaksen Jaksen^f
Ade_silvia@polsri.ac.id^{b*}

Politeknik Negeri Sriwijaya^{abcd},
Universitas Palembang^e

Intisari

Kata kunci:
rekomendasi tanaman,
sensor tanah 8-in-1,
Machine Learning,
klasifikasi, kesesuaian
lahan, rekomendasi
tanaman

Pemilihan jenis tanaman yang sesuai dengan kondisi tanah merupakan faktor penting dalam meningkatkan produktivitas pertanian. Penelitian ini bertujuan mengembangkan sistem rekomendasi tanaman berbasis data kondisi tanah yang diperoleh dari sensor tanah 8-in-1. Parameter yang digunakan meliputi suhu tanah, kelembaban tanah, pH, *electrical conductivity* (EC), nitrogen (N), fosfor (P), kalium (K), dan tingkat kesuburan tanah. Dataset yang digunakan terdiri dari 500 data yang dikelompokkan ke dalam lima jenis tanaman, yaitu kelapa sawit, kelapa, padi, jagung, dan pisang. Proses klasifikasi dilakukan dengan membandingkan beberapa algoritma *machine learning* menggunakan metode *Nested Cross Validation* untuk memperoleh model terbaik. Evaluasi dilakukan menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. Hasil pengujian menunjukkan bahwa algoritma *Decision Tree* memberikan performa terbaik dengan akurasi 95,6%, *precision* 0,952, *recall* 0,957, dan *F1-score* 0,958. Hasil analisis *confusion matrix* menunjukkan bahwa sebagian besar data berhasil diklasifikasikan dengan benar pada setiap kelas tanaman. Temuan penelitian ini menunjukkan bahwa algoritma *Decision Tree* mampu mengidentifikasi kesesuaian tanaman berdasarkan karakteristik tanah secara efektif dan berpotensi diterapkan sebagai sistem pendukung keputusan pada sektor pertanian.

Tentang naskah:
-diterima, 20 Juni 2026
-diterbitkan, 1 Juli 2026

Abstract

Selecting suitable crops based on soil conditions is an important factor in improving agricultural productivity. This study aims to develop a crop recommendation system based on soil condition data obtained from an 8-in-1 soil sensor. The parameters used include soil temperature, soil moisture, pH, electrical conductivity (EC), nitrogen (N), phosphorus (P), potassium (K), and soil fertility. The dataset consisted of 500 observations categorized into five crop types: oil palm, coconut, rice, corn, and banana. The classification process was conducted by comparing several machine learning algorithms using the Nested Cross Validation method to obtain the best-performing model. Model performance was evaluated using accuracy, precision, recall, and F1-score metrics. The results showed that the Decision Tree algorithm achieved the best performance, with an accuracy of 95.6%, precision of 0.952, recall of 0.957, and an F1-score of 0.958. The confusion matrix analysis indicated that most samples were correctly classified across all crop categories. These findings demonstrate that the Decision Tree algorithm is effective in identifying crop suitability based on soil characteristics and has the potential to be implemented as a decision support system for agricultural applications.

Keywords:
crop recommendation, 8-in-1 soil sensor, Decision Tree, machine learning, decision tree, classification, land suitability.

1. Pendahuluan

Sektor pertanian dan perkebunan memiliki peran penting dalam mendukung ketahanan pangan dan pertumbuhan ekonomi Indonesia Kabupaten Banyuasin merupakan salah satu wilayah di Provinsi Sumatera Selatan yang memiliki potensi besar pada komoditas pertanian dan perkebunan, seperti kelapa sawit, kelapa, padi, jagung, dan pisang. Produktivitas tanaman tersebut dipengaruhi oleh berbagai parameter tanah, antara lain suhu, kelembaban, pH, electrical conductivity (EC), serta kandungan unsur hara makro berupa nitrogen (N), fosfor (P), dan kalium (K). Oleh karena itu, pemilihan jenis tanaman dan pemberian pupuk yang sesuai dengan kondisi tanah menjadi faktor penting dalam mendukung produktivitas lahan.(Shams et al., 2024)

Dalam praktiknya, keputusan terkait pemilihan tanaman dan pemupukan masih banyak didasarkan pada pengalaman atau kebiasaan petani. Pendekatan tersebut berpotensi menyebabkan ketidaksesuaian antara karakteristik tanah dan kebutuhan tanaman sehingga dapat menurunkan produktivitas lahan serta efisiensi penggunaan pupuk. Kondisi ini menunjukkan perlunya sistem yang mampu memberikan rekomendasi berdasarkan data kondisi tanah yang terukur..

Perkembangan Internet of Things (IoT) memungkinkan pemantauan kondisi tanah secara real-time melalui berbagai jenis sensor. Salah satu perangkat yang banyak digunakan adalah sensor tanah 8-in-1 yang mampu mengukur suhu tanah, kelembaban tanah, pH, EC, nitrogen, fosfor, dan kalium secara bersamaan. Data yang diperoleh dari sensor tersebut dapat dimanfaatkan sebagai dasar pengambilan keputusan dalam pengelolaan lahan pertanian.(Song et al., 2023)

Seiring perkembangan kecerdasan buatan, machine learning telah banyak diterapkan untuk mendukung klasifikasi tanaman, analisis kesesuaian lahan, dan sistem rekomendasi berbasis data (Ryo, 2022). Salah satu algoritma yang banyak digunakan adalah Decision Tree karena mampu menghasilkan model yang mudah dipahami serta memiliki kemampuan klasifikasi yang baik. Namun, sebagian besar penelitian sebelumnya masih menggunakan jumlah parameter tanah yang terbatas atau hanya melakukan pengukuran pada satu titik pengamatan.

Padahal, kondisi tanah dapat bervariasi pada lokasi yang berbeda di sekitar tanaman sehingga berpotensi memengaruhi hasil rekomendasi yang dihasilkan.(Ryo, 2022)

Berdasarkan permasalahan tersebut, penelitian ini mengembangkan sistem rekomendasi tanaman menggunakan data kondisi tanah yang diperoleh dari sensor tanah 8-in-1. Pengambilan data dilakukan pada tiga titik pengamatan, yaitu di dekat batang tanaman (0 meter), radius 1 meter, dan radius 2 meter untuk memperoleh representasi kondisi tanah yang lebih menyeluruh. Data yang diperoleh kemudian diolah menggunakan algoritma Decision Tree dan dibandingkan dengan beberapa algoritma klasifikasi lainnya menggunakan metode Nested Cross Validation.

Kontribusi penelitian ini terletak pada pemanfaatan data kondisi tanah hasil pengukuran langsung dari sensor tanah 8-in-1 pada beberapa titik pengamatan untuk menghasilkan rekomendasi tanaman berbasis machine learning. Pendekatan ini diharapkan mampu memberikan rekomendasi yang lebih representatif terhadap kondisi lahan serta mendukung pengambilan keputusan dalam pengelolaan pertanian secara lebih efektif.

2. Kerangka Teori


2.1. Internet of Things (IoT)

Banyak sektor seperti bisnis, kesehatan, transportasi, dan pertanian telah dipengaruhi oleh Internet of Things (IoT) karena memungkinkan proses pengumpulan, pengiriman, penyimpanan, dan pengolahan data secara real-time, yang memungkinkan pengambilan keputusan yang lebih cepat dan akurat..(Schmidinger et al., 2024).

IoT digunakan dalam sektor pertanian untuk memantau kondisi lahan dan lingkungan secara berkelanjutan melalui berbagai jenis sensor. Sensor ini dapat mengumpulkan data untuk mengetahui kondisi lahan seperti suhu, kelembaban, tingkat keasaman (pH), kandungan unsur hara, dan parameter lainnya. Informasi ini dapat membantu petani mengelola lahan dengan lebih baik.

Istilah "pertanian cerdas" atau "pertanian pintar" digunakan untuk menggambarkan implementasi Internet of Things (IoT) dalam pertanian, yang

mencakup penerapan teknologi sensor, perangkat komunikasi, dan sistem pengolahan data untuk meningkatkan produktivitas pertanian. Sistem pemantauan berbasis IoT memantau kondisi tanah secara real-time, yang memungkinkan petani untuk segera mengetahui jika ada perubahan dalam kondisi lahan dan kemudian mengambil tindakan.



Gambar 1. Arsitektur Sistem IoT


Teknologi Internet of Things (IoT) digunakan dalam penelitian ini untuk mengumpulkan data tentang kondisi tanah. Sensor tanah 8-in-1 dapat mengukur suhu, pH, kelembaban, kapasitas listrik (EC), nitrogen (N), fosfor (P), dan kalium (K). Selanjutnya, data dikirim ke sistem, dan algoritma machine learning digunakan untuk membuat rekomendasi untuk tanaman yang sesuai dengan kondisi tanah dan untuk pemupukan.

Studi ini menunjukkan bahwa penggunaan Internet of Things (IoT) akan memungkinkan penyediaan data berkelanjutan dan real-time tentang kondisi tanah. Akibatnya, sistem rekomendasi yang dikembangkan diharapkan dapat memberikan informasi yang lebih akurat dan membantu proses pengambilan keputusan tentang pengelolaan lahan pertanian dan perkebunan di Kabupaten Banyuasin.

2.2. Pertanian Presisi

Pertanian presisi (Precision Agriculture) adalah pendekatan modern dalam pengelolaan lahan pertanian yang memanfaatkan teknologi untuk memperoleh informasi kondisi lahan secara akurat dan real-time (Eladl et al., 2024). Idenya adalah untuk meningkatkan produktivitas pertanian dengan membuat keputusan yang didasarkan pada data aktual di lapangan, sehingga penggunaan sumber daya seperti air, pupuk, dan tenaga kerja dapat dilakukan secara lebih efisien.

Teknologi seperti Machine learning, Internet of Things (IoT), dan sensor telah mempercepat penggunaan teknologi pertanian dalam berbagai kegiatan pertanian. Berdasarkan karakteristik tanah yang diamati, data yang diperoleh dari sensor dapat digunakan untuk memantau kondisi tanah, menemukan kebutuhan tanaman, dan menentukan tindakan yang tepat.




Gambar 2. Konsep pertanian presisi berbasis data kondisi tanah.

Dalam penelitian ini, konsep pertanian presisi diterapkan dengan mengukur kondisi tanah dengan menggunakan sensor tanah 8-in-1. Selanjutnya, algoritma Decision Tree digunakan untuk menganalisis data yang diperoleh dan membuat rekomendasi untuk tanaman dan pemupukan yang sesuai dengan kondisi tanah di Kabupaten Banyuasin. Metode ini memungkinkan pengambilan keputusan budidaya berbasis data dan lebih objektif daripada metode konvensional.

2.3. Sensor Tanah 8-in-1

Sensor tanah 8-in-1 banyak digunakan dalam bidang pertanian cerdas (smart farming) karena mampu memberikan informasi kondisi tanah secara cepat dan akurat. Perangkat ini dapat digunakan untuk mengukur berbagai parameter

kondisi tanah secara bersamaan dalam satu alat, yang memungkinkan proses pengambilan data menjadi lebih efisien.



Gambar 3. Soil Sensor 8 in 1

8-in-1 sensor tanah dapat mengukur suhu, kelembaban, tingkat keasaman, kapasitas listrik (EC), kandungan nitrogen (N), fosfor (P), dan kalium (K). Semua ketujuh kriteria ini sangat penting dan memengaruhi pertumbuhan tanaman dan tingkat kesuburan tanah (Senapaty et al., 2023). Data yang diperoleh dari sensor dapat digunakan untuk menentukan jenis tanaman yang tepat dan jumlah pemupukan yang ideal.


Dalam penelitian ini, sensor tanah 8-in-1 digunakan sebagai sumber data utama untuk memperoleh kondisi tanah pada berbagai jenis lahan pertanian dan perkebunan di Kabupaten Banyuwasin. Pengukuran dilakukan pada tiga titik pengamatan, yaitu dekat batang tanaman (0 meter), radius 1 meter, dan radius 2 meter. Data hasil pengukuran selanjutnya digunakan sebagai fitur masukan pada algoritma Decision Tree untuk menghasilkan rekomendasi tanaman dan pemupukan berdasarkan kondisi tanah yang terukur.

2.4. Machine Learning

Sistem komputer yang tidak diprogram secara eksplisit untuk membuat keputusan dan mempelajari pola data dapat dilakukan oleh machine learning, cabang dari kecerdasan buatan (AI). Untuk mencapai tujuan ini, model yang dibuat

dari data masa lalu digunakan untuk proses prediksi dan klasifikasi data baru. Karena kemampuan ini, machine learning telah banyak digunakan di banyak bidang, termasuk kesehatan, bisnis, transportasi, dan pertanian.(Elbasi et al., 2024).

Machine Learning digunakan dalam sektor pertanian untuk membantu proses pengambilan keputusan berbasis data seperti prediksi hasil panen, identifikasi penyakit tanaman, klasifikasi jenis tanaman, analisis kesuburan tanah, dan rekomendasi pemupukan. Dengan menggunakan data dari sensor dan perangkat IoT, machine learning mampu menghasilkan informasi yang lebih akurat dan tidak bias dibandingkan dengan metode konvensional yang hanya bergantung pada pengalaman peneliti.




Gambar 4. Tahapan umum proses Machine Learning.

machine learning biasanya dibagi menjadi tiga kategori utama: pembelajaran yang diawasi, pembelajaran yang tidak diawasi, dan pembelajaran yang didukung. Karena data digunakan dengan label atau target, penelitian ini menggunakan pendekatan pembelajaran yang diawasi. Rekomendasi pemupukan dan jenis tanaman digunakan sebagai target klasifikasi, dan data kondisi tanah digunakan sebagai fitur tambahan.

Penelitian ini bertujuan untuk mengevaluasi hubungan antara kondisi tanah dan kebutuhan tanaman melalui penggunaan machine learning. Diharapkan model tersebut dapat menggunakan parameter tanah yang diperoleh dari sensor 8-in-1, untuk menyarankan tanaman dan pemupukan yang tepat. Akibatnya, proses pengambilan keputusan menjadi lebih cepat, akurat, dan berbasis data.

2.5. Algoritma Decision Tree

Decision Tree adalah algoritma pembelajaran terawasi yang digunakan untuk menyelesaikan masalah klasifikasi dan prediksi (Hasanah et al., 2021). Algoritma ini bekerja dengan membentuk struktur pohon yang terdiri dari root node, internal node, dan leaf node. Setiap node mewakili karakteristik tertentu, yang digunakan sebagai dasar pengambilan keputusan untuk menghasilkan kelas atau kategori akhir. (Rexlin Freeda, n.d.).



Gambar 5. Ilustrasi proses klasifikasi menggunakan algoritma Decision Tree.

Dalam proses pembentukan Decision Tree, atribut yang memiliki kemampuan terbaik untuk memisahkan data dipilih dengan menggunakan perhitungan entropy dan pendapatan informasi. Entropy mengukur tingkat ketidakpastian data, dan pendapatan informasi mengidentifikasi atribut yang paling berpengaruh dalam proses klasifikasi (Ma et al., 2025).

Persamaan Entropy dapat dituliskan sebagai berikut:

$$Entropy(S) = - \sum_{i=1}^n p_i \log_2(p_i)$$

di mana (p_i) merupakan probabilitas kemunculan kelas ke-(i) pada himpunan data (S).

Selanjutnya, Information Gain dihitung menggunakan persamaan:

$$Gain(S, A) = Entropy(S) - \sum_{v \in Values(A)} \frac{|S_v|}{|S|} Entropy(S_v)$$


Algoritma Decision Tree digunakan dalam penelitian ini untuk mengklasifikasikan jenis tanaman dan membuat rekomendasi pemupukan berdasarkan parameter kondisi tanah yang diperoleh dari sensor 8-in-1. Parameter yang digunakan termasuk suhu

tanah, kelembaban tanah, pH, EC, nitrogen, fosfor, dan kalium. Semua parameter ini diperoleh pada tiga titik pengukuran yang berbeda (Motamedi & Villányi, 2024). Hasil klasifikasi kemudian digunakan untuk membuat saran yang sesuai dengan kondisi lahan.

2.6. Sistem Rekomendasi Tanaman dan Pemupukan

Dalam bidang pertanian, sistem rekomendasi membantu petani dalam membuat keputusan yang tepat tentang jenis tanaman apa yang harus ditanam dan berapa banyak pemupukan yang diperlukan sesuai dengan kondisi lahan (Tanaka et al., 2024).

Sebagai input utama dalam penelitian ini, sistem rekomendasi menggunakan data kondisi tanah dari sensor tanah 8-in-1. Parameter yang digunakan adalah kelembaban tanah, suhu tanah, pH, kapasitas listrik (EC), nitrogen (N), fosfor (P), dan kalium (K). pengukuran dilakukan pada tiga titik pengamatan, yaitu di dekat batang tanaman (0 meter), radius 1 meter, dan radius 2. Selanjutnya, algoritma Decision Tree digunakan untuk memproses data untuk menghasilkan rekomendasi yang tepat (Dey et al., 2024).




Gambar 6. Alur sistem rekomendasi tanaman dan pemupukan.

Jenis tanaman yang disarankan dalam penelitian ini termasuk kelapa sawit, kelapa, jagung, padi, pisang, dan kelapa. Selain itu, sistem juga memberikan rekomendasi pemupukan yang tepat untuk mendukung pertumbuhan tanaman dan meningkatkan produktivitas lahan.

Diharapkan sistem rekomendasi ini akan membantu petani dan pengelola lahan memilih strategi budidaya yang paling sesuai dengan kondisi tanah mereka. Ini memungkinkan proses pengambilan keputusan yang lebih cepat, objektif, dan berbasis data.

kelembaban tanah, konduktivitas listrik, pH tanah, nitrogen (N), fosfor (P), kalium (K), dan Kesuburan Tanah adalah beberapa parameter yang diukur. Data dikumpulkan dari berbagai tanaman, seperti kelapa, kelapa sawit, padi, jagung, dan pisang.



Gambar 9. Diagram Alur Penelitian

Lima ratus data yang digunakan dalam penelitian dibagi secara seimbang ke dalam lima kelas tanaman, masing-masing terdiri dari seratus data untuk kelapa sawit, kelapa, padi, jagung, dan pisang. Untuk mengevaluasi kondisi tanah, pelatihan dan pengujian model klasifikasi digunakan sebagai dasar untuk membuat rekomendasi tanaman.

3.2. Preprocessing Data

Tahap preprocessing dilakukan sebelum data digunakan pada proses pemodelan machine learning untuk memastikan kualitas dan konsistensi data. Tahapan ini meliputi pembersihan data, ekstraksi nilai numerik dari hasil pengukuran sensor, serta normalisasi label tanaman. Selanjutnya, data dikelompokkan ke dalam lima kelas tanaman, yaitu kelapa sawit, kelapa, padi, jagung, dan pisang.

Setelah proses preprocessing selesai, data dipisahkan menjadi fitur dan label. Fitur yang digunakan meliputi suhu tanah, kelembaban tanah, konduktivitas listrik (EC), pH, nitrogen, fosfor, kalium, dan kesuburan tanah, sedangkan label yang digunakan adalah jenis tanaman. Tahap ini bertujuan untuk memastikan data siap digunakan pada proses pelatihan dan pengujian model klasifikasi.

3.3. Pemodelan Machine Learning

Studi ini melakukan perbandingan algoritma klasifikasi yang berbeda. Algoritma-algoritma ini termasuk Random

Forest, Decision Tree, Support Vector Machine (SVM), K-Nearest Neighbor (KNN), XGBoost, Gaussian Naive Bayes, dan Logistic Regression. Setiap model dilatih dengan dataset yang sama untuk mendapatkan hasil evaluasi yang objektif (Prity et al., 2024).

Penggunaan metode Nested Cross Validation berbasis Stratified Group K-Fold untuk pelatihan dan pengujian model mengurangi risiko overfitting dan menghasilkan evaluasi performa yang lebih stabil. Model yang paling cocok dipilih berdasarkan nilai akurasi, Precision, Recall, dan skor F1 yang diperoleh selama tahap evaluasi (Steinert et al., 2024).

3.4. Evaluasi Model

Evaluasi model dilakukan untuk mengukur kemampuan algoritma dalam mengklasifikasikan jenis tanaman berdasarkan parameter kondisi tanah. Penelitian ini menggunakan empat metrik evaluasi, yaitu accuracy, precision, recall, dan F1-score. Accuracy digunakan untuk mengukur tingkat Precision prediksi secara keseluruhan, precision untuk mengukur Precision hasil prediksi pada setiap kelas, recall untuk mengukur kemampuan model dalam mengenali data yang sebenarnya, sedangkan F1-score digunakan untuk menilai keseimbangan antara precision dan recall.

Selain metrik evaluasi, penelitian ini juga menggunakan Confusion Matrix untuk menganalisis hasil klasifikasi pada setiap kelas tanaman. Confusion Matrix digunakan untuk menentukan berapa banyak data yang berhasil diklasifikasikan dengan benar dan berapa banyak yang mengalami kesalahan klasifikasi. Hasil evaluasi ini digunakan sebagai dasar untuk menentukan model yang paling cocok untuk sistem rekomendasi tanaman dan pemupukan.

3.5. Alur Penelitian

Penelitian diawali dengan proses pengumpulan data kondisi tanah menggunakan sensor tanah 8-in-1. Data yang diperoleh kemudian melalui tahap preprocessing sebelum digunakan pada proses pemodelan machine learning. Selanjutnya, beberapa algoritma klasifikasi dilatih dan diuji menggunakan metode Nested Cross Validation.

Hasil evaluasi setiap model dibandingkan berdasarkan nilai accuracy,

precision, recall, dan F1-score. Model dengan performa terbaik dipilih sebagai model utama untuk menghasilkan rekomendasi tanaman berdasarkan kondisi tanah yang diamati.

4. Hasil dan Pembahasan

4.1. Exploratory Data Analysis

Sebelum digunakan dalam proses pelatihan model pelatihan mesin, analisis data eksploratif (EDA) dilakukan untuk mengetahui karakteristik dataset. Penelitian ini menggunakan lima ratus data kondisi tanah yang dikategorikan ke dalam lima kelas tanaman: kelapa sawit, kelapa, padi, jagung, dan pisang. Karena setiap kelas memiliki seratus data, data didistribusikan seimbang antar kelas. Kondisi ini sangat penting untuk mengurangi kemungkinan adanya model bias terhadap kelas tertentu selama proses klasifikasi.

Table 1. Dataset Kondisi Tanah

No	Desc	Temp	Moisture	Conductivity	pH	Nitrogen	Phosphor	Kalium	Fertility
1	Sawit 1	30.8°C	7.9%	0.0us/cm	7.0	0mg/kg	0mg/kg	0mg/kg	0mg/kg
2	Sawit 2	30.9°C	7.9%	0.0us/cm	7.0	0mg/kg	0mg/kg	0mg/kg	0mg/kg
3	sawit 9	31.0°C	9.7%	5.0us/cm	7.0	0mg/kg	0mg/kg	0mg/kg	2mg/kg
4	sawit 4	31.0°C	0.0%	0.0us/cm	7.0	0mg/kg	0mg/kg	0mg/kg	0mg/kg
5	sawit 5	30.6°C	9.6%	0.0us/cm	7.0	0mg/kg	0mg/kg	0mg/kg	0mg/kg

Menurut analisis awal, delapan parameter utama terdiri dari kumpulan data: suhu tanah (suhu), kelembaban tanah (lembapan), konduktivitas listrik (konduktivitas), nitrogen (N), fosfor (P), kalium (K), dan Kesuburan Tanah. Parameter-parameter tersebut memiliki rentang nilai yang berbeda yang sesuai dengan masing-masing karakteristik tanaman. Variasi nilai pada setiap parameter menunjukkan bahwa kondisi tanah antar tanaman memiliki pola yang berbeda, yang dapat digunakan sebagai fitur dalam proses klasifikasi.

Menurut analisis awal, delapan parameter utama terdiri dari kumpulan data: suhu tanah (suhu), kelembaban tanah (lembapan), konduktivitas listrik (konduktivitas), nitrogen (N), fosfor (P), kalium (K), dan Kesuburan Tanah. Parameter-parameter tersebut memiliki rentang nilai yang berbeda yang sesuai dengan masing-masing karakteristik tanaman. Variasi nilai pada setiap parameter menunjukkan bahwa kondisi tanah antar tanaman memiliki pola yang berbeda, yang dapat digunakan sebagai fitur dalam proses klasifikasi.


4.2. Hasil Pengujian Model

Pengujian model dilakukan untuk melihat bagaimana berbagai algoritma klasifikasi bekerja untuk mengidentifikasi jenis tanaman berdasarkan parameter kondisi tanah yang digunakan dalam penelitian ini. Decision Tree, Random Forest, Support Vector Machine (SVM), K-Nearest Neighbor (KNN), Gaussian Naive Bayes, XGBoost, dan Logistic Regression adalah algoritma yang diuji.

Tabel 2. Hasil Pengujian Akurasi Model

Model	Akurasi
Decision Tree	0.956
Random Forest	0.894
SVM	0.845
K-Nearest Neighbor	0.832
Gaussian Naïve Bayes	0.811
XGBoost	0.801
Logistic Regression	0.797

Menurut Tabel 2, algoritma Decision Tree menghasilkan nilai akurasi tertinggi sebesar 95,6%, diikuti oleh Random Forest sebesar 89,4% dan SVM sebesar 84,5%. Nilai akurasi K-Nearest Neighbor sebesar 83,2%, Gaussian Naïve Bayes sebesar 81,1%, XGBoost sebesar 80,1%, dan Logistic Regression sebesar 79,7%. Hasil ini menunjukkan bahwa algoritma berbasis Decision Tree lebih baik dalam mengklasifikasikan jejak.



Gambar 10. Perbandingan Akurasi Model Klasifikasi

Dengan akurasi sebesar 95,6%, Decision Tree unggul dibandingkan model lain, seperti yang ditunjukkan pada Gambar 10. Perbedaan nilai akurasi yang signifikan menunjukkan bahwa struktur Decision Tree dapat menggambarkan dengan baik hubungan antara berbagai parameter kondisi tanah, termasuk konduktivitas, suhu, kelembaban, pH, kandungan nitrogen, fosfor, kalium, dan tingkat kesuburan. Decision Tree tidak hanya memiliki akurasi tertinggi, tetapi juga memiliki keunggulan dalam

interpretasi hasil karena aturan klasifikasi yang dihasilkannya mudah dipahami.

Hasil pengujian menunjukkan bahwa algoritma Decision Tree memperoleh akurasi tertinggi dibandingkan algoritma lainnya, yaitu sebesar 95,6%. Performa tersebut mengindikasikan bahwa pola hubungan antara parameter kondisi tanah dan jenis tanaman pada dataset penelitian dapat dipisahkan dengan baik melalui aturan keputusan berbentuk pohon. Kondisi ini menunjukkan bahwa karakteristik setiap kelas tanaman memiliki batasan nilai parameter tanah yang cukup jelas sehingga mampu diidentifikasi secara efektif oleh algoritma Decision Tree.

4.3. Evaluasi Performa Model Klasifikasi

Untuk mengetahui kemampuan masing-masing algoritma klasifikasi untuk membedakan jenis tanaman berdasarkan parameter kondisi tanah, evaluasi performa model dilakukan. Dalam penelitian ini, metrik Precision, Recall, dan F1-Score digunakan untuk evaluasi. Precision mengukur tingkat Precision prediksi model terhadap kelas yang diprediksi, Recall mengukur kemampuan model untuk mengidentifikasi semua data pada kelas yang sebenarnya, dan F1-Score adalah rata-rata harmonis antara Precision dan Recall untuk mengevaluasi performa model secara keseluruhan.

Tabel 3. Hasil Evaluasi Performa Model

Model	Precision	Recall	F1-Score
Decision Tree	0.952	0.957	0.958
Random Forest	0.891	0.885	0.874
SVM	0.849	0.846	0.835
K-Nearest Neighbor	0.837	0.831	0.832
Gaussian Naïve Bayes	0.803	0.814	0.811
XGBoost	0.804	0.797	0.801
Logistic Regression	0.786	0.796	0.797

Tabel 3 menunjukkan bahwa algoritma Decision Tree memperoleh nilai precision tertinggi sebesar 0,952, nilai recall sebesar 0,957, dan nilai F1-Score sebesar 0,958. Nilai precision yang tinggi menunjukkan bahwa sebagian besar prediksi yang

dihasilkan model sesuai dengan kelas sebenarnya, sehingga

Dengan nilai Precision sebesar 0,891, Recall sebesar 0,885, dan F1-Score sebesar 0,874, Random Forest menempati posisi kedua. Meskipun algoritma SVM bekerja dengan baik, hasil yang diperoleh masih berada di bawah Decision Tree. Selain itu, algoritma K-Nearest Neighbor dan algoritma SVM menunjukkan kinerja yang baik dengan nilai F1-Score masing-masing 0,835 dan 0,832. Hal ini menunjukkan bahwa kedua algoritma masih memiliki kemampuan untuk melakukan klasifikasi dengan tingkat Precision yang cukup tinggi, tetapi mereka masih belum dapat menyamai kinerja algoritma berbasis Decision Tree.

Nilai F1-Score Logistic Regression, Gaussian Naive Bayes, dan XGBoost masing-masing 0,811, 0,801, dan 0,797. Hasil menunjukkan bahwa ketiga algoritma masih dapat digunakan untuk proses klasifikasi, tetapi masing-masing memiliki kemampuan yang lebih rendah daripada yang lain. Perbedaan kinerja ini menunjukkan bahwa pendekatan Decision Tree lebih cocok untuk menunjukkan hubungan antar parameter tanah dalam dataset penelitian daripada metode statistik atau model linear.

Selain memperoleh akurasi tertinggi, algoritma Decision Tree juga menunjukkan nilai precision, recall, dan F1-score yang lebih baik dibandingkan model lainnya. Hal ini menunjukkan bahwa model tidak hanya mampu menghasilkan prediksi yang tepat secara keseluruhan, tetapi juga memiliki kemampuan yang baik dalam mengenali setiap kelas tanaman. Konsistensi nilai evaluasi tersebut mengindikasikan bahwa model memiliki keseimbangan yang baik antara kemampuan klasifikasi dan kemampuan generalisasi terhadap data yang diuji.

4.4. Pembahasan Hasil Eksperimen

Hasil pengujian dan evaluasi menunjukkan bahwa algoritma Decision Tree adalah yang terbaik dibandingkan dengan algoritma lain. Algoritma ini memiliki akurasi 95,6%, Precision 0,952, recall 0,957, dan skor F1 0,958. Hasil ini menunjukkan bahwa algoritma ini mampu mempelajari hubungan antara parameter kondisi tanah seperti suhu, kelembaban, konduktivitas, pH, nitrogen, fosfor, kalium, dan fertilitas dengan jenis

tanaman yang berbeda. Nilai yang tinggi pada setiap metrik evaluasi menunjukkan bahwa model memiliki kemampuan yang baik untuk membuat ramalan yang akurat dan konsisten untuk setiap kelas tanaman.

Selain itu, hasil matrix confusion menunjukkan bahwa sebagian besar data diklasifikasikan dengan benar; hanya ada satu kesalahan klasifikasi pada kelas padi, sedangkan kelapa dan sawit memiliki tingkat klasifikasi sempurna dengan semua data diprediksi dengan benar; kesalahan prediksi hanya terjadi pada beberapa data jagung, yang diprediksi sebagai pisang, dan sebaliknya. Kondisi ini menunjukkan bahwa karakteristik tanah kedua tanaman tersebar luas.

Secara keseluruhan, hasil eksperimen menunjukkan bahwa algoritma Decision Tree dapat melakukan tugas klasifikasi yang sangat baik dalam menentukan jenis tanaman berdasarkan kondisi tanah. Selain menghasilkan akurasi yang tinggi, model ini juga memiliki keunggulan dalam interpretasi karena pengguna dapat dengan mudah memahami aturan keputusan yang dibuat. Akibatnya, Decision Tree dinilai cocok untuk digunakan pada sistem rekomendasi tanaman dan pemupukan yang dikembangkan dalam penelitian ini yang berbasis Internet of Things (IoT). Dengan demikian, sistem tersebut dapat membantu proses pengambilan keputusan berbasis data yang lebih cepat.

Keunggulan algoritma Decision Tree pada penelitian ini diduga dipengaruhi oleh karakteristik dataset yang memiliki hubungan yang relatif jelas antara parameter kondisi tanah dan jenis tanaman. Setiap tanaman memiliki kebutuhan kondisi tanah yang berbeda, seperti tingkat kelembaban, pH, kandungan unsur hara, dan tingkat kesuburan tertentu. Decision Tree mampu membentuk aturan keputusan berdasarkan nilai ambang pada setiap parameter sehingga proses pemisahan kelas dapat dilakukan secara bertahap dan lebih efektif.

Dibandingkan dengan algoritma seperti Logistic Regression dan Support Vector Machine, Decision Tree lebih mampu menangkap pola nonlinier yang terdapat pada data kondisi tanah. Selain itu, seluruh parameter yang digunakan pada penelitian ini memiliki keterkaitan langsung dengan karakteristik lahan sehingga struktur pohon yang terbentuk

dapat merepresentasikan hubungan antar parameter dengan baik. Kondisi ini menyebabkan Decision Tree memperoleh performa yang lebih tinggi dibandingkan algoritma lainnya.

Meskipun Random Forest dan XGBoost merupakan algoritma yang lebih kompleks, hasil pengujian menunjukkan bahwa peningkatan kompleksitas model tidak selalu menghasilkan akurasi yang lebih baik. Pada dataset penelitian ini, pola klasifikasi antar kelas tanaman telah dapat dipisahkan dengan baik menggunakan struktur pohon keputusan tunggal. Oleh karena itu, Decision Tree menjadi pilihan yang lebih sesuai karena mampu menghasilkan performa tinggi sekaligus menyediakan aturan keputusan yang mudah dipahami dan diinterpretasikan oleh pengguna.

5. Simpulan

Penelitian ini berhasil mengembangkan sistem rekomendasi tanaman berdasarkan kondisi tanah menggunakan sensor tanah 8-in-1 dan algoritma Decision Tree. Hasil pengujian menunjukkan bahwa algoritma Decision Tree memperoleh performa terbaik dengan akurasi sebesar 95,6%, precision 95,2%, recall 95,7%, dan F1-score 95,8%. Hasil tersebut menunjukkan bahwa parameter kondisi tanah yang diukur oleh sensor dapat dimanfaatkan secara efektif untuk proses klasifikasi tanaman. Pada penelitian selanjutnya, jumlah data dan jenis tanaman dapat diperluas untuk meningkatkan kemampuan generalisasi model.

Ucapan Terima Kasih

Pengakuan

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada semua pihak yang telah mendukung penelitian ini. Penelitian ini didanai oleh Program Berdikari di bawah Program Bantuan Operasional Perguruan Tinggi Negeri (BOPTN) – Program Penelitian Baru Tahun Anggaran 2026, Kementerian Pendidikan Tinggi, Ilmu Pengetahuan, dan Teknologi Republik Indonesia (Kementerian Pendidikan Tinggi, Sains, dan Teknologi), berdasarkan Kontrak Nomor 207/C3/DT.05.00/PL-Baru/2026, berdasarkan SP DIPA-139.04.1.693320/2026 revisi 01 tanggal 24 Desember 2025.

Penelitian dilaksanakan di Laboratorium Teknik Telekomunikasi Politeknik Negeri Sriwijaya bekerjasama dengan mitra UKM melalui Dinas Koperasi dan UKM Sumatera Selatan dan Rumah Kopi Sriwijaya, dengan dukungan strategis dari Hanns R. Neumann Stiftung (HRNS) dan PT Komiko Cipta Solusi. Kontribusi berharga, dukungan teknis, dan kerja sama mereka sangat kami hargai.

Daftar Pustaka

- Dey, B., Ferdous, J., & Ahmed, R. (2024). Machine learning based recommendation of agricultural and horticultural crop farming in India under the regime of NPK, soil pH and three climatic variables. *Heliyon*, 10(3). <https://doi.org/10.1016/j.heliyon.2024.e25112>
- Eladl, S. G., Haikal, A. Y., Saafan, M. M., & ZainEldin, H. Y. (2024). A proposed plant classification framework for smart agricultural applications using UAV images and artificial intelligence techniques. *Alexandria Engineering Journal*, 109, 466–481. <https://doi.org/10.1016/j.aej.2024.08.076>
- Elbasi, E., Mostafa, N., Zaki, C., AlArnaout, Z., Topcu, A. E., & Saker, L. (2024). Optimizing Agricultural Data Analysis Techniques through AI-Powered Decision-Making Processes. *Applied Sciences (Switzerland)*, 14(17). <https://doi.org/10.3390/app14178018>
- Hasanah, M. A., Soim, S., & Handayani, A. S. (2021). Implementasi CRISP-DM Model Menggunakan Metode Decision Tree dengan Algoritma CART untuk Prediksi Curah Hujan Berpotensi Banjir. In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 5, Number 2). <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Ma, H., Zhao, G., Peng, B., Chen, B., Rong, Y., & Li, Y. (2025). Rapid Detection System of Paddy Impurities Based on Machine Vision. *Journal of Food Processing and Preservation*, 2025(1). <https://doi.org/10.1155/jfpp/2338160>
- Motamedi, B., & Villányi, B. (2024). A predictive analytics model with Bayesian-Optimized Ensemble Decision Trees for enhanced crop recommendation. *Decision Analytics Journal*, 12. <https://doi.org/10.1016/j.dajour.2024.100516>
- Prity, F. S., Hasan, M. M., Saif, S. H., Hossain, M. M., Bhuiyan, S. H., Islam, M. A., & Lavlu, M. T. H. (2024). Enhancing Agricultural Productivity: A Machine Learning Approach to Crop Recommendations. *Human-Centric Intelligent Systems*, 4(4), 497–510. <https://doi.org/10.1007/s44230-024-00081-3>
- Rexlin Freeda, A. (n.d.). *INTERNATIONAL JOURNAL OF PROGRESSIVE RESEARCH IN ENGINEERING MANAGEMENT AND SCIENCE (IJPREMS) STUDY PAPER: DECISION TREE ALGORITHMS IN MACHINE LEARNING*. Retrieved www.ijprems.com
- Ryo, M. (2022). Explainable artificial intelligence and interpretable machine learning for agricultural data analysis. *Artificial Intelligence in Agriculture*, 6, 257–265. <https://doi.org/10.1016/j.aiaa.2022.11.003>
- Schmidinger, J., Barkov, V., Tavakoli, H., Correa, J., Ostermann, M., Atzmueller, M., Gebbers, R., & Vogel, S. (2024). Which and how many soil sensors are ideal to predict key soil properties: A case study with seven sensors. *Geoderma*, 450. <https://doi.org/10.1016/j.geoderma.2024.117017>
- Shams, M. Y., Gamel, S. A., & Talaat, F. M. (2024). Enhancing crop recommendation systems with explainable artificial intelligence: a study on agricultural decision-making. *Neural Computing and Applications*, 36(11), 5695–5714. <https://doi.org/10.1007/s00521-023-09391-2>
- Song, T., Si, Y., Gao, J., Wang, W., Nie, C., & Klemeš, J. J. (2023). Prediction and monitoring model for farmland environmental system using soil sensor and neural network algorithm. *Open Physics*, 21(1). <https://doi.org/10.1515/phys-2022-0224>
- Steinert, S., Ruf, V., Dzsojtjan, D., Großmann, N., Schmidt, A., Kuhn, J., & Küchemann, S. (2024). A refined approach for evaluating small datasets via binary classification using machine learning. *PLoS ONE*, 19(5 May). <https://doi.org/10.1371/journal.pone.0301276>
- Tanaka, T. S. T., Heuvelink, G. B. M., Mieno, T., & Bullock, D. S. (2024). Can machine learning models provide accurate fertilizer recommendations? *Precision Agriculture*, 25(4), 1839–1856. <https://doi.org/10.1007/s11119-024-10136-x>